

Avaliação do método de classificação baseada no objeto em imagens de alta resolução espacial aplicado para o monitoramento de faixa de dutos: estudo de caso no entorno da refinaria de Capuava, Mauá-SP

Bruna Christofolletti Mazzeo¹

Marcelo Elias Delaneze¹

Mara Lúcia Marques¹

Paulina Setti Riedel¹

¹ Universidade Estadual Paulista - UNESP
Caixa Postal 178 - 13506-795 – Rio Claro - SP, Brasil
brunamaz@gmail.com.br

Abstract. The Metropolitan Region of São Paulo is the most populous of the country, this happens because of their great economic importance on the national scene. This fact results in intense population growth and urban expansion, reaching some non-habitable places of the metropolis, as areas of pipelines, which are very important for the transportation of natural gas, oil and its derivatives. With the disorderly occupation is generated great anthropogenic pressure on the ducts, causing risks to people who are close to them. Therefore, this study aims to monitor a stretch of pipeline GASPAL / OSVAT and Capuava Refinery (RECAP), located on the outskirts of the metropolitan area of São Paulo in the city of Mauá, using remote sensing and GIS. The monitoring was performed by the object classification based on satellite images Ikonos and RapidEye, and image processing, detection of objects, segmentation, classification and editing were developed through the eCognition and ArcGIS. To determine the statistical accuracy of the mapping of land cover the stretch of pipeline in Maua, the results were analyzed by matrix errors and the Kappa coefficient. The results presented in the paper show that the methodological procedure of classification based on the object presents itself as a good alternative for monitoring pipeline ranges, as well as the use of high resolution image sensors.

Palavras-chave: remote sensing, urban expansion, pipeline monitoring, sensoriamento remoto, expansão urbana, monitoramento de dutos.

1. Introdução

As malhas dutoviárias estão presentes no Brasil desde 1942, segundo Gasparini (2006), quando o país optou por modernizar o sistema de transporte de petróleo, resultando em um dos mais seguros e eficazes meios de escoamento de óleo, gás natural, produtos químicos, biocombustíveis, entre outros derivados. As dutovias são a melhor opção para territórios de grande extensão e de diferentes cenários naturais e artificiais como o Brasil, pois o material do duto foi criado para resistir a diversos ambientes como mares, áreas fluviais, diferentes vegetações, áreas habitadas como pequenas comunidades ou até mesmo grandes complexos urbanos, como as metrópoles.

No entanto, apesar de toda segurança que o empreendimento apresenta, deve-se estar preparado para qualquer possível acidente, pois, de acordo com a CETESB (2009), logo após a instalação do duto, este passa a sofrer influência do ambiente, assim como, causa influência sobre o mesmo. Portanto, as faixas de dutos estão susceptíveis a sofrer intemperismos através de fenômenos naturais e pressões antrópicas, dependendo do local onde está instalado, podendo, então, trazer riscos de explosões, deslizamentos, vazamentos e outros, prejudicando as populações, o meio ambiente e também o transporte de petróleo. As faixas de dutos que passam por cidades ou áreas de intensa urbanização devem ser levadas em consideração, pelo fato desses locais estarem em movimentação constante e apresentarem rápidas mudanças, diferente dos ambientes naturais que tendem mudar mais lentamente. Em 2000, havia aproximadamente 62.800 habitantes nas áreas próximas das faixas de dutos na Região Metropolitana de São Paulo (IBGE apud SÃO PAULO, 2007).

Desse modo, se não houver o monitoramento e controle das faixas de dutos, assim como a manutenção do local e das faixas, e quando possível, o planejamento e ordenamento urbano, a

população residente da área e a atividade de transporte de petróleo estarão ameaçados. As geotecnologias providas do sensoriamento remoto e do geoprocessamento são ferramentas fundamentais para o auxílio do monitoramento da faixa de dutos em ambiente densamente urbanizado. Portanto, coube ao presente estudo o objetivo de avaliar se o método de classificação orientado a objeto em imagens de alta resolução espacial mostraria resultados significativos para o monitoramento da faixa de duto na cidade de Mauá, pertencente a grande região metropolitana de São Paulo, área extremamente conurbada. E também, comprovar que as geotecnologias, como softwares e imagens orbitais, juntamente do sensoriamento remoto e o geoprocessamento, são ferramentas fundamentais no auxílio da organização urbana.

A área de estudo selecionada para este trabalho, possui 8,27 Km² e compreende a Refinaria de Capuava (RECAP) e um trecho da faixa de dutos OSVAT, localizadas na cidade de Mauá. O Município de Mauá está inserido na grande Região Metropolitana de São Paulo e tem grande importância econômica dentro da mesma.

3. Material e métodos

Para cumprir os objetivos propostos foram utilizadas duas imagens óticas de alta resolução espacial, uma do sensor Ikonos II e outra Rapideye. As características das imagens utilizadas estão descritas na Tabela 1.

Tabela 1. Propriedades das imagens utilizadas.

| Data | Ângulo de elevação do imageamento | Azimute do imageamento | Ângulo de elevação solar | Azimute solar |
|------------|-----------------------------------|------------------------|--------------------------|---------------|
| 09/09/2011 | 86,63 | 2,79 | 84,12 | 2,47 |
| 25/11/2011 | 86,28 | 115,05 | 68,39 | 87,25 |

Com a intenção de avaliar a classificação de diferentes imagens de alta resolução espacial aplicadas em áreas de faixa de duto em regiões urbanas, foi escolhida a metodologia de classificação baseada a objeto, o desenvolvimento da aplicação desse processo será descrito nos itens a seguir.

3.1 Pré-processamento das imagens

Para a interpretação e análise das imagens digitais torna-se necessário compreender o comportamento espectral dos objetos que compõe a área de estudo. As técnicas de tratamento digital das imagens viabilizam o reconhecimento e interpretação das informações espaciais. O pré-processamento foi realizado apenas para a imagem Ikonos II, pois a RapidEye já vem ortorretificada, com um nível muito bom de correção. Por tanto, para a Ikonos foi feito a correção geométrica, que se consiste no processo de ortorretificação, que acontece transformando a rotação e translação da imagem com finalidade de que ela se ajuste nos parâmetros de uma imagem já registrada. Com isso selecionam-se pontos de controle na imagem a ser registrada e na que já está ortorretificada, depois disso aplica-se modelos matemáticos computacional para finalizar (JENSEN, 1996).

Além do registro da imagem foi aplicada também a técnica de fusão, que consiste na combinação de imagens distintas com finalidade de se obter um produto resultante da síntese das imagens de qualidade superior (PINHO, 2006). Para o fim dessa primeira etapa, foi feito o recorte da área de estudo nas imagens RapidEye e Ikonos, escolhendo a área que melhor se encaixava nos parâmetros do trabalho, como as faixas de duto e as áreas de intensa ocupação urbana.

3.2 Classificação de imagens com diferentes resoluções

A segmentação para as imagens Ikonos II e RapidEye foram feitas pelo algoritmo de segmentação multiresolução, do software eCognition 8.0, que permite a criação de objetos da imagem em diferentes escalas de detalhamento. Este procedimento se pauta no crescimento de regiões, na qual regiões adjacentes são ajuntadas através do parâmetro de similaridade que pondera a heterogeneidade intrínseca às mesmas. Na definição da similaridade é necessário fornecer os parâmetros de escala, forma, tonalidade, compacidade, suavidade, bandas espectrais (BAATZ e SCHÄPE, 2000).

Para esse trabalho, foram criadas dezesseis classes de acordo com o tipo de característica apresentadas na área de estudo, com isso, as mesmas foram agrupadas de acordo com seus atributos semelhantes, separando-as de maneira hierárquica. Seguiu-se a hierarquia para classificar as imagens Ikonos II e RapidEye no software eCognition 8.0 através do processo de classificação baseado no objeto nas imagens foi realizado pela ferramenta Assign Class do programa computacional.

De acordo com a estrutura hierárquica de classes, foram selecionadas amostras de cada classe de cobertura da terra nas duas imagens. A amostragem é fundamental para a descrição das classes e para o contexto que estão inseridas, quanto mais amostras se selecionar nas imagens, mais possibilidades de acertos na classificação, pois aumenta a abrangência de cores, facilitando a separação dos parâmetros e dos seus valores, dessa forma, através da ferramenta Sample Editor, do eCognition 8.0, se faz a análise dos histogramas de atributos que são geradas pelo Editor de amostras. Após as etapas já descritas foi executado o procedimento de classificação, através do software eCognition 8.0 pela abordagem baseada a objeto, e a elaboração dos mapas de cobertura da terra no ArcMap 10.

3.3 Avaliação estatística das classes nas imagens com diferentes resoluções

Os mapas de cobertura da terra gerados foram exportados para o ArcMap 10, onde se comparou os resultados dos mesmos com quatrocentos e cinquenta pontos coletados, cinquenta pontos para cada classe, nas imagens orbitais Ikonos e RapidEye. Posteriormente, para se fazer a comparação de acertos e erros da classificação do mapa, foram utilizados métodos estatísticos, a partir da matriz de erros e do índice Kappa. Depois da visualização dos resultados da estatística, foi feita a edição dos mapas de cobertura da terra em comparação e sobreposição com as imagens dos sensores, com o objetivo de corrigir erros de alguns segmentos que se encontravam em classes erradas. Com o mapa editado fez-se novamente a análise dos erros através da Matriz de erros e do método Kappa.

Foram classificadas as classes e os resultados dos mapas de cobertura da terra através da proposta de Landis e Koch (1977), representada na tabela a seguir:

Tabela 2. Qualidade da classificação associada ao índice Kappa.

| Índice Kappa | Desempenho da Classificação |
|--------------------|-----------------------------|
| $0 < K \leq 0,2$ | Ruim |
| $0,2 < K \leq 0,4$ | Razoável |
| $0,4 < K \leq 0,6$ | Bom |
| $0,6 < K \leq 0,8$ | Muito bom |
| $0,8 < K \leq 1,0$ | Excelente |

Fonte: Adaptado de Landis e Koch (1977).

4. Resultados e Discussões

Os resultados da classificação baseada no objeto, gerada no software eCognition 8.0 Developer, em imagens de alta resolução espacial, aplicados no monitoramento da faixa de dutos, foram apresentados em formas de mapa e analisados de acordo com a matriz de erros e o coeficiente de concordância Kappa. O mapa de cobertura da terra da imagem RapidEye, apresentado na Figura 1, teve o valor de acerto, de acordo com a matriz de erro, de 64% e o coeficiente de concordância Kappa foi de 0,59. Por tanto, segundo a caracterização dos valores propostos por Landis e Koch (1977), a classificação baseada no objeto na imagem RapidEye foi Boa, representando uma adequada precisão das classes expostas na cena.

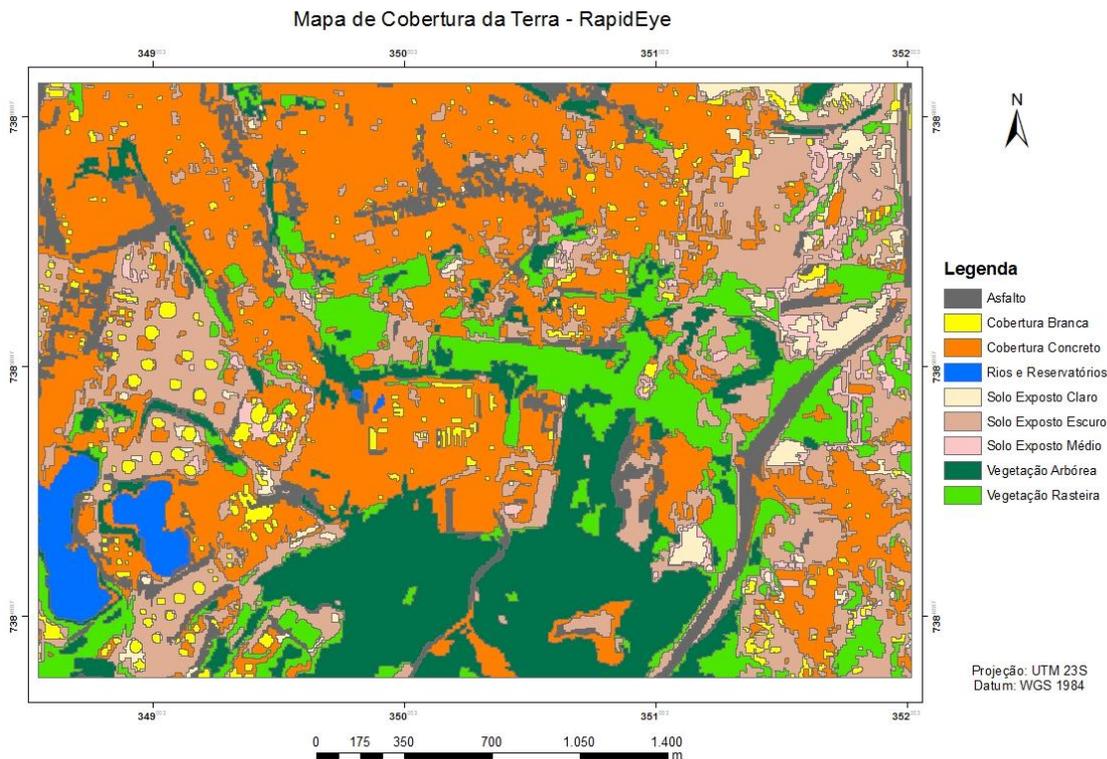


Figura 1. Mapa da cobertura da terra na imagem RapidEye.

Na Matriz de erros, a melhor classificação foi obtida pela classe Rios e Reservatórios, tendo um acerto de 92%, resultando em um acerto da acurácia do usuário em 100% e na acurácia do produtor em 92% mostrados na Tabela 3. No entanto, a classe Solo Exposto Médio mostrou o pior resultado da tabela, tendo apenas um total de 28% de acertos dos pontos da matriz de erros em sua própria classe, isso acontece por essa classe estar no intervalo de outras duas classes, sendo que essas três juntas, representam uma classe maior: Solo Exposto.

Tabela 3. Kappa condicional das classes de cobertura da terra pela imagem RapidEye

| Classe de Cobertura da terra | Acurácia do usuário (%) | Kappa (usuário) | Acurácia do produtor (%) | Kappa (produtor) |
|------------------------------|-------------------------|-----------------|--------------------------|------------------|
| Asfalto | 62 | 0,57 | 42 | 0,37 |
| Cobertura Branca | 79 | 0,76 | 90 | 0,89 |
| Cobertura Escura | 41 | 0,34 | 68 | 0,61 |
| Solo Exposto Claro | 65 | 0,60 | 44 | 0,39 |
| Solo Exposto Médio | 64 | 0,59 | 28 | 0,24 |

| | | | | |
|----------------------|-----|------|----|------|
| Solo Exposto Escuro | 33 | 0,25 | 58 | 0,48 |
| Vegetação Arbórea | 90 | 0,89 | 76 | 0,74 |
| Vegetação Rasteira | 83 | 0,80 | 76 | 0,73 |
| Rios e Reservatórios | 100 | 1,00 | 92 | 0,91 |

Para a imagem Ikonos II, o mapa de cobertura da terra, mostrado na Figura 3, teve os valores de 61 % de acerto geral na matriz de erros e 0,56 no coeficiente de concordância. Apesar dos valores mais baixos que o mapa de cobertura a terra feito através da imagem RapidEye, o resultado para a imagem Ikonos, de acordo com a tabela Landis e Koch (1977), é também a de uma Boa classificação.

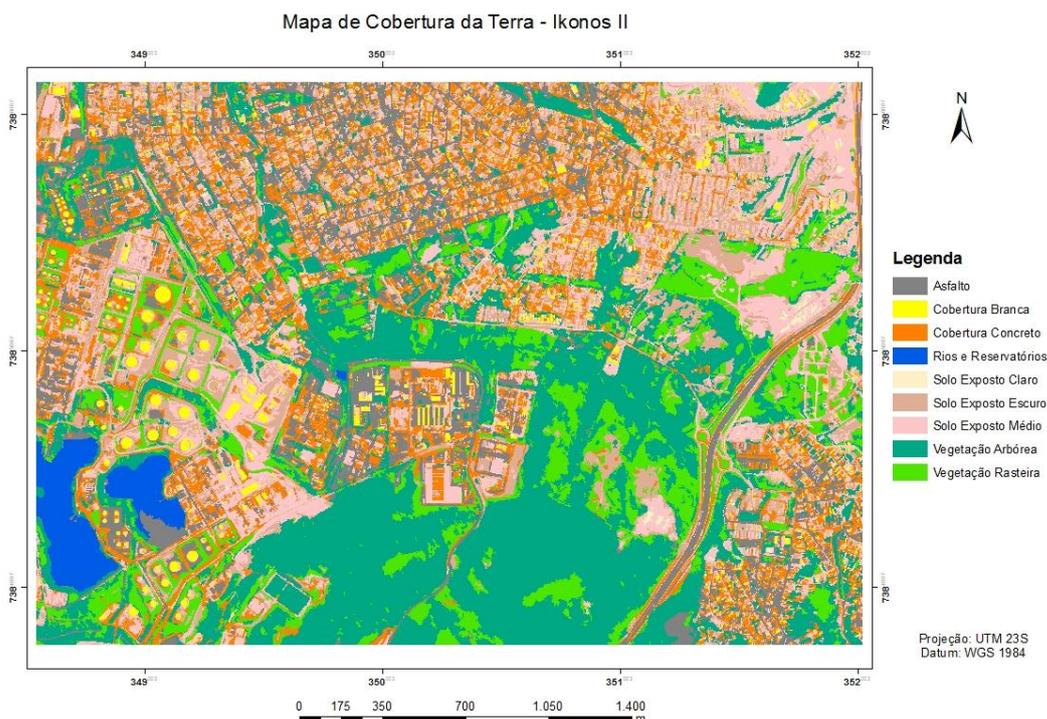


Figura 2. Mapa da cobertura da terra na imagem Ikonos II.

Na Matriz de erros, as classes que apresentaram menos acertos, também foram as de Solos Expostos, havendo muita alteração de segmentos entre essas três classes, como mostrado na Tabela 4. A classe que mais se destaca por acertos é a Vegetação Arbórea, apresentando um acerto geral de 98% dos pontos coletados, com a acurácia do produtor de 98% e o Kappa do produtor de 0,98. As outras classes utilizadas para o mapeamento se apresentaram com um bom acerto geral.

Tabela 4. Kappa condicional das classes de cobertura da terra pela imagem IkonosII

| Classe de Cobertura da terra | Acurácia do usuário (%) | Kappa (usuário) | Acurácia do produtor (%) | Kappa (produtor) |
|------------------------------|-------------------------|-----------------|--------------------------|------------------|
| Asfalto | 55 | 0,49 | 78 | 0,74 |
| Cobertura Branca | 94 | 0,93 | 88 | 0,87 |
| Cobertura Escura | 46 | 0,39 | 22 | 0,18 |
| Solo Exposto Claro | 80 | 0,78 | 24 | 0,21 |
| Solo Exposto Médio | 36 | 0,28 | 54 | 0,45 |
| Solo Exposto Escuro | 39 | 0,31 | 64 | 0,56 |
| Vegetação Arbórea | 70 | 0,66 | 98 | 0,98 |
| Vegetação Rasteira | 91 | 0,90 | 62 | 0,59 |

| | | | | |
|----------------------|-----|------|----|------|
| Rios e Reservatórios | 100 | 1,00 | 62 | 0,59 |
|----------------------|-----|------|----|------|

Os resultados obtidos na edição do mapa de cobertura da terra, apresentado na Figura 3, da imagem RapidEye foram de 70% de acerto geral e 0,65 para o coeficiente Kappa. A nova classificação, de acordo com a definição de Landis e Koch (1977), caracterizada antes como Boa, após a edição passa a ser considerada Muito boa. A única classe que ainda permanece com o número baixo de acertos na própria classe é a de Solo Exposto Médio que cai o número de acertos de 14 para 13, com o resultado da acurácia do usuário em 65% e acurácia do produtor em 26%, como descrito na Tabela 5. No entanto, as duas outras classes de solos exposto aumentam os acertos classificados dentro das suas classes.

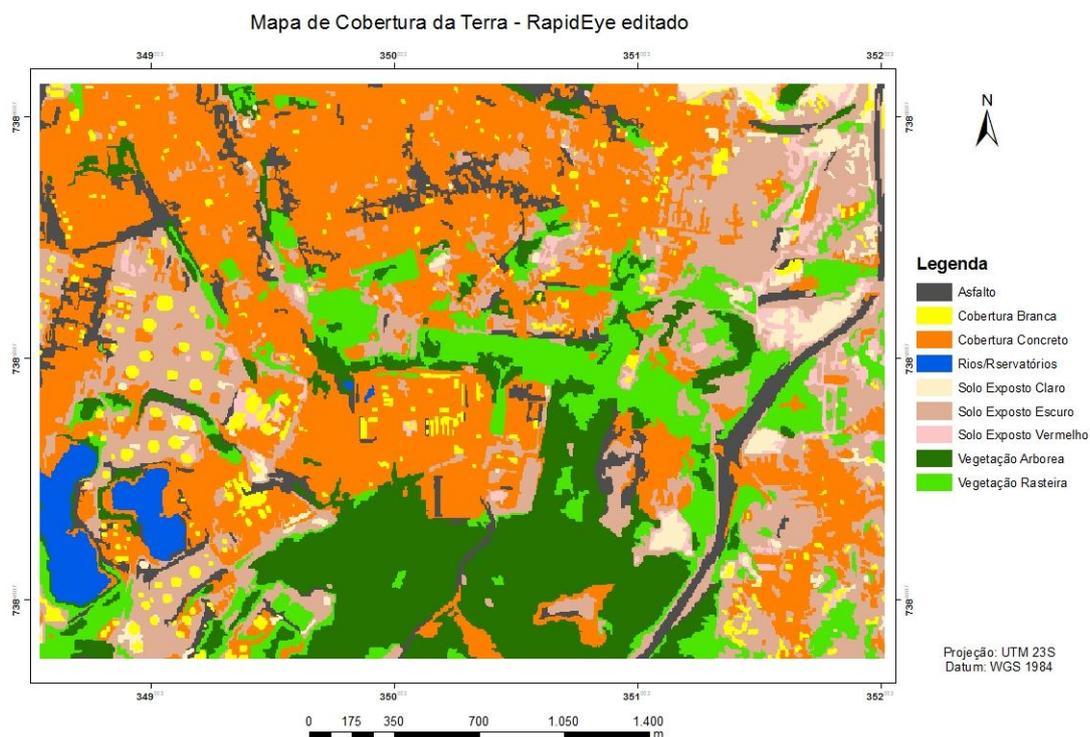


Figura 3. Mapa da cobertura da terra na imagem RapidEye editado.

Tabela 5. Kappa condicional das classes de cobertura da terra pela imagem RapidEye editada

| Classe de Cobertura da terra | Acurácia do usuário (%) | Kappa (usuário) | Acurácia do produtor (%) | Kappa (produtor) |
|------------------------------|-------------------------|-----------------|--------------------------|------------------|
| Asfalto | 70 | 0,66 | 42 | 0,38 |
| Cobertura Branca | 88 | 0,87 | 90 | 0,89 |
| Cobertura Escura | 51 | 0,45 | 76 | 0,71 |
| Solo Exposto Claro | 70 | 0,67 | 62 | 0,58 |
| Solo Exposto Médio | 65 | 0,61 | 26 | 0,23 |
| Solo Exposto Escuro | 43 | 0,35 | 80 | 0,75 |
| Vegetação Arborea | 90 | 0,89 | 76 | 0,74 |
| Vegetação Rasteira | 85 | 0,83 | 78 | 0,75 |
| Rios e Reservatórios | 100 | 1,00 | 96 | 0,96 |

Com a edição aplicada no mapa da cobertura da terra, feito sobre a imagem RapidEye, foi possível alcançar um aumento de 6% na sua acurácia do mesmo com o real. Apesar da classificação ter subido do nível Bom para o Muito bom segundo a comparação de Landis e Koch (1977), a edição só não foi melhor porque, os polígonos gerados na imagem após feito o processo de segmentação no eCognition, são maiores que muitas coberturas da terra

representadas na imagem. Ou seja, apesar de se ter buscado a melhor segmentação para a imagem RapidEye, essa apresentou polígonos que abrangiam mais de uma classe.

Na edição da classificação da imagem Ikonos, foi gerado um novo mapa, Figura 4, no qual se percebeu mais mudanças do que na edição da classificação da outra imagem. Isso ocorre porque a resolução espacial do sensor Ikonos II é maior e melhor que a do RapidEye, pois apresenta menor escala o que permite fazer uma maior distinção dos alvos terrestres. Dessa forma, quando a imagem Ikonos foi segmentada ela se fragmentou em objetos bem menores que as da imagem RapidEye, separando melhor as coberturas da terra representadas na imagem, permitindo uma coleta mais eficiente das amostras para a definição dos valores.

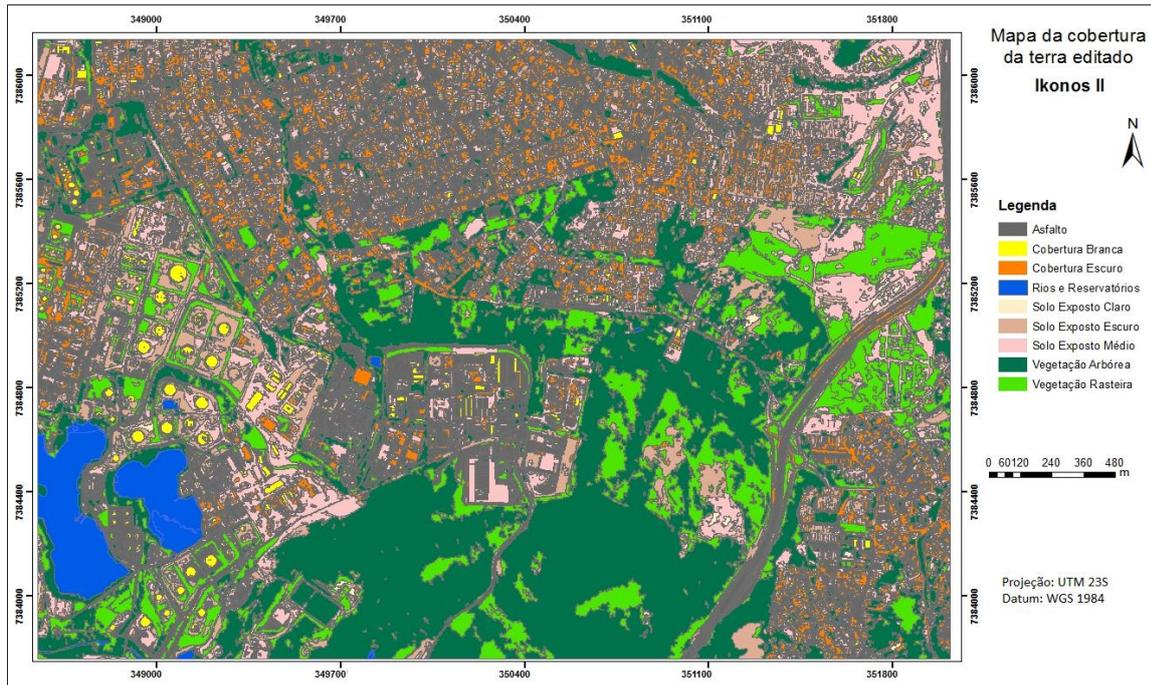


Figura 4. Mapa da cobertura da terra na imagem Ikonos II editado.

Então, após a edição notou-se que a definição da classificação do mapa de cobertura da terra passou de 61% de acerto geral na matriz de erro para 67% e o parâmetro de Kappa passou de 0,56 para 0,63 como aparece na Tabela 6. Por tanto, também subiu a qualidade da classificação desse mapa após adição, passando de Boa para Muito boa. As classes em geral também aumentaram seus acertos, no entanto a Cobertura Escura se confunde com a classe Asfalto e com o Solo Exposto Médio, já que dentro dessa classe encontram valores dos espectros terrestres muito semelhantes. Essa confusão de valores também ocorre para as classes de Solo Exposto, pois estes apresentam características muito parecidas.

Tabela 6. Kappa condicional das classes de cobertura da terra pela imagem IkonosII editada

| Classe de Cobertura da terra | Acurácia do usuário (%) | Kappa (usuário) | Acurácia do produtor (%) | Kappa (produtor) |
|------------------------------|-------------------------|-----------------|--------------------------|------------------|
| Asfalto | 69 | 0,66 | 86 | 0,84 |
| Cobertura Branca | 96 | 0,95 | 88 | 0,87 |
| Cobertura Escura | 65 | 0,61 | 26 | 0,23 |
| Solo Exposto Claro | 85 | 0,83 | 34 | 0,31 |
| Solo Exposto Médio | 30 | 0,22 | 54 | 0,43 |
| Solo Exposto Escuro | 52 | 0,46 | 66 | 0,60 |
| Vegetação Arbórea | 72 | 0,68 | 96 | 0,95 |

| | | | | |
|----------------------|-----|------|----|------|
| Vegetação Rasteira | 89 | 0,88 | 66 | 0,63 |
| Rios e Reservatórios | 100 | 1,00 | 90 | 0,89 |

5. Conclusões

Após as análises dos resultados pode-se considerar que a classificação baseada no objeto aplicado em imagens de alta resolução espacial, se apresentou como uma eficaz metodologia, principalmente quando as imagens são de áreas complexas como os espaços urbanos. Dessa forma, fica evidente a contribuição das geotecnologias para a análise sócio-espacial em espaços urbanos, assim como, para o monitoramento de dutos. Esse tipo de abordagem baseada no objeto pode ser utilizado juntamente de outros métodos para melhor monitoramento e acompanhamento de mudanças na superfície da terra, como por exemplo, o monitoramento temporal, pois esse apresentará não apenas a caracterização do fenômeno; ocupação e pressão antrópica nas faixas de dutos; no espaço, mas dará também a espacialidade das mudanças que esse fenômeno causa.

Com relação ao emprego das imagens de alta resolução espacial no monitoramento de faixa de dutos, deve-se considerar que a imagem RapidEye apresentou melhores resultados nos métodos estáticos de Matriz de erros e no coeficiente Kappa, apesar dessa ter uma escala maior que a imagem Ikonos, ou seja, sua resolução espacial é menor que a Ikonos, ela foi capaz de apresentar mais eficiência na classificação do mapa da cobertura da terra. Contudo, cabe destacar que a imagem Ikonos apresenta muito mais detalhes espaciais e espectrais que a RapidEye, possibilitando uma melhor análise do real na imagem, porém, a classificação da mesma se torna muito mais difícil e complexa. Para futuros trabalhos recomenda-se, grande atenção para se fazer a classificação da imagem Ikonos. Sugere-se também, que quando aplicado o método de classificação baseado no objeto na imagem Ikonos II, deve-se criar mais classes, separando essas nas determinadas ordens e hierarquias, pois essa imagem apresenta uma grande quantidade de detalhes e quando esses não são separados em diversas classes, podem atrapalhar a criação do mapa de cobertura da terra, confundindo valores parecidos que não pertencem à mesma classe.

6. Referências Bibliográficas

BAATZ, M.; SCHÄPE, A. **Multi resolution segmentation: an optimization approach for high quality multiscale image segmentation**. In: XII Angewandte Geographische Informationsverarbeitung, Wichmann-Verlag, Heidelberg, 2000.

CETESB (Companhia de Tecnologia de Saneamento Ambiental). **Dutos no estado de São Paulo**. 2009. Disponível em: <<http://www.cetesb.sp.gov.br>>. Acesso em: 30 ago. 2012.

GASPARINI, A. **Transporte Dutoviário e Meio Ambiente. O Controle da Rede de Dutos Terrestres da Petrobrás Operadas pela Transpetro**. André Gasparini. _Rio de Janeiro, RJ, 2006.

JENSEN, J. R. **Introductory digital image processing: a remote sensing perspective**. 2ed. New Jersey: Prentice Hall, 1996.

LANDIS, J. R.; KOCH, G. G. **The measurement of observer agreement of categorical data**. *Biometrics*, 33 (1), 159-174, 1977.

PINHO, C. M. D. **Análise Orientada a Objetos de Imagens de Satélite de Alta Resolução Espacial Aplicada na Classificação de Cobertura do Solo no Espaço Intra-Urbano: O Caso de São José dos Campos**. Dissertação de Mestrado, INPE. 2006.

SÃO PAULO (SMA). **RIMA – Relatório de Impacto Ambiental Plano Diretor de Dutos de São Paulo (PDD/SP)**. Secretaria do Meio Ambiente do Estado de São Paulo, São Paulo: Petrobrás, 1 p. 2007.